

# PENDETEKSIAN DINI KRISIS KEUANGAN DI INDONESIA MENGUNAKAN GABUNGAN MODEL VOLATILITAS DENGAN MARKOV *SWITCHING* BERDASARKAN INDIKATOR KONDISI PERBANKAN

(Studi Kasus Pada Indikator Selisih Suku Bunga Pinjaman dengan Simpanan, Suku Bunga Simpanan Riil, dan Selisih BI *Rate* Riil dengan Fed *Rate* Riil)

Shania Puspita Sari, Sugiyanto, dan Etik Zukhronah  
Program Studi Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Sebelas Maret Surakarta

ABSTRAK. Krisis keuangan yang telah berkali-kali menerpa Indonesia membuat perlu adanya pendeteksian dini untuk meminimalisir dampak krisis. Salah satu metode yang dapat digunakan untuk mendeteksi krisis adalah dengan memodelkan data indikator krisis menggunakan model gabungan Markov *switching* dan volatilitas. Pada artikel ini dibahas model gabungan Markov *switching* dan volatilitas terbaik untuk indikator selisih suku bunga pinjaman dengan simpanan, suku bunga simpanan riil, dan selisih BI *rate* riil dengan Fed *rate* riil serta pendeteksian dini krisis keuangan berdasarkan nilai *smoothed probability*. Model terbaik yang diperoleh untuk ketiga indikator tersebut yaitu model *MS-GARCH* dengan 3-*state*. Krisis pada tahun 1997 berhasil terdeteksi oleh nilai *smoothed probability* dari ketiga indikator pada batas tertentu. Prediksi untuk tahun 2017 menunjukkan tidak ada tanda-tanda akan terjadi krisis.

**Kata kunci:** *pendeteksian, krisis, MS-GARCH, perbankan, suku bunga*

## 1. PENDAHULUAN

Krisis keuangan merupakan kondisi memburuknya keuangan suatu negara yang ditandai dengan kenaikan tingkat inflasi secara drastis, nilai tukar mata uang yang anjlok, serta penurunan aktifitas perekonomian lainnya. Krisis keuangan telah berkali-kali melanda Indonesia, salah satunya pada tahun 1997 yang menyebabkan beban negara dalam menanggung hutang luar negeri masih terasa hingga saat ini. Melihat akibat dari krisis keuangan terhadap penurunan kegiatan ekonomi membuat sistem peringatan dini diperlukan guna mengantisipasi terjadinya krisis di masa yang akan datang. Kaminsky *et al.* [4] mengembangkan sistem pendeteksian dini untuk krisis ekonomi dengan mengamati perkembangan beberapa indikator yang menunjukkan perilaku tidak biasa ketika krisis terjadi. Diperoleh 15 indikator yang dapat digunakan untuk mendeteksi krisis, tiga diantaranya yaitu selisih suku bunga pinjaman dengan simpanan, suku bunga simpanan riil dan selisih suku bunga riil domestik dengan luar negeri. Ketiga indikator suku bunga tersebut dapat menggambarkan kondisi perbankan di Indonesia sehingga dapat dikatakan sebagai indikator kondisi perbankan.

Suku bunga simpanan merupakan tingkat bunga yang diberikan bank kepada nasabah atas simpanannya. Suku bunga pinjaman adalah tingkat bunga yang diberikan bank kepada nasabah atas pinjamannya. Suku bunga simpanan riil merupakan suku bunga simpanan yang dikurangi dengan tingkat inflasi. Selisih suku bunga riil domestik dengan luar negeri diwakilkan dengan data selisih BI *rate* riil dengan Fed *rate* riil. BI *rate* riil adalah suku bunga acuan bank sentral Indonesia

yang telah dikurangi tingkat inflasi di Indonesia. Fed *rate* riil adalah suku bunga acuan bank sentral Amerika yang telah dikurangi tingkat inflasi di Amerika.

Indikator kondisi perbankan diindikasikan memiliki efek heterokedastisitas sehingga harus dimodelkan menggunakan model volatilitas. Model volatilitas yang diperoleh digabungkan dengan model Markov *switching* dengan asumsi tiga *state* untuk mengatasi adanya perbedaan antara kondisi stabil, rawan, dan krisis.

Penelitian tentang krisis berdasarkan gabungan model volatilitas dan Markov *switching* pernah dilakukan oleh Mwamba dan Majadibodu [6] yang mengidentifikasi krisis mata uang Afrika Selatan berdasarkan indikator valuta asing menggunakan model *MS-GARCH(1,1)*. Salah satu alternatif pendeteksian krisis ekonomi menggunakan gabungan model volatilitas dengan Markov *switching* yaitu dengan melihat nilai *smoothed probability* pada *state* tertentu. Pada artikel ini dibahas penentuan model yang sesuai untuk data dan pendeteksian krisis keuangan di Indonesia pada tahun 2017 berdasarkan indikator selisih suku bunga pinjaman dengan simpanan, suku bunga simpanan riil, dan selisih BI *rate* riil dengan Fed *rate* riil.

## 2. LANDASAN TEORI

**2.1. Model Rata-Rata.** Data runtun waktu yang tidak stasioner dapat distasionerkan menggunakan transformasi log *return* yang dapat dituliskan sebagai  $r_t = \ln(\frac{Z_t}{Z_{t-1}})$  dimana  $Z_t$  adalah data pada saat  $t$  dan  $Z_{t-1}$  adalah data saat  $(t - 1)$ . Data yang sudah stasioner dapat dimodelkan menggunakan model *Autoregressive Moving Average (ARMA)*. Model *ARMA(p,q)* dapat dirumuskan sebagai

$$r_t = \phi_1 r_{t-1} + \phi_2 r_{t-2} + \dots + \phi_p r_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} + a_t,$$

dengan  $r_t$  adalah nilai log *return* pada periode ke- $t$ ,  $\phi_1, \dots, \phi_p$  adalah parameter model *AR*,  $\theta_1, \dots, \theta_q$  adalah parameter model *MA* dan  $a_t$  adalah residu periode ke- $t$  (Tsay [8]).

**2.2. Model Volatilitas.** Residu dari model *ARMA* yang mengandung efek heterokedastisitas dapat dimodelkan menggunakan model volatilitas dimana residu tersebut yaitu  $a_t$  dapat dinyatakan sebagai

$$a_t = \sigma_t \epsilon_t \text{ untuk } \epsilon_t \sim N(0, 1) \text{ dan } a_t | F_{t-1} \sim N(0, \sigma_t^2),$$

dengan  $\epsilon_t$  adalah residu terstandar model *ARMA* serta  $F_{t-1}$  adalah himpunan semua informasi pada periode  $t - 1$ .

**2.2.1. Autoregressive Conditional Heteroscedastic (ARCH).** Model (*ARCH(m)*) dapat dituliskan sebagai

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i a_{t-i}^2,$$

dengan  $\alpha_0$  adalah konstanta model,  $\alpha_i$  adalah parameter model *ARCH*,  $m$  adalah orde model *ARCH* dan  $\sigma_t^2$  adalah variansi residu periode ke- $t$  (Tsay [8]).

2.2.2. **Generalized ARCH (GARCH).** Orde yang terlalu tinggi pada model *ARCH* dapat diatasi menggunakan *GARCH* ( $m, s$ ) yang dapat dituliskan sebagai

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i a_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2,$$

dengan  $\beta$  adalah parameter model *GARCH* (Tsay [8]).

2.2.3. **Exponential GARCH (EGARCH).** Masalah Leverage {effect pada model *GARCH* dapat diatasi oleh model *EGARCH*( $m, s$ ) yang dapat dituliskan sebagai

$$\ln \sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i \left( \left| \frac{a_{t-i}}{\sqrt{\sigma_{t-i}^2}} \right| - \sqrt{\frac{2}{\pi}} \right) + \sum_{i=1}^m \gamma_i \frac{a_{t-i}}{\sqrt{\sigma_{t-i}^2}} + \sum_{j=1}^s \beta_j \ln \sigma_{t-j}^2.$$

dengan  $\gamma$  adalah parameter Leverage *effect* (Tsay [8]).

2.3. **Model Markov Switching.** Menurut Hamilton and Susmel [2], model Markov *switching* untuk rata-rata bersyarat dapat dituliskan sebagai

$$r_t = \mu_{s_t} + \tilde{r}_t$$

dengan  $r_t$  adalah log *return* pada waktu ke- $t$ ,  $\tilde{r}_t$  mengikuti proses *ARMA*( $p, q$ ) dengan rata-rata nol, dan  $\mu_{s_t}$  adalah rata-rata pada *state* saat ke- $t$ .

2.4. **Gabungan Model Volatilitas dan Markov Switching.**

2.4.1. **Markov Switching-GARCH (MS-GARCH).** Menurut Gray [1], *MS-GARCH*( $m, s$ ) dapat dituliskan sebagai

$$\sigma_{t,s_t}^2 = \alpha_{0,s_t} + \sum_{i=1}^m \alpha_{i,s_t} a_{t-i}^2 + \sum_{j=1}^s \beta_{j,s_t} \sigma_{t-j}^2.$$

2.5. **Smoothed Probability.** Menurut Chung [5], nilai *smoothed probability* yaitu  $P(S_t = i | Z^T; \theta)$  dirumuskan sebagai

$$P(S_t = i | Z^T; \theta) = \sum_{s=1}^3 P(S_{t+1} = s | Z^T; \theta) P(S_t = i | S_{t+1} = s, Z^T; \theta).$$

Menurut Sopipan *et al.*[7], secara umum peramalan *smoothed probability* dapat ditentukan melalui peramalan pada waktu  $t + 1$  yang didasarkan pada *smoothed probability* saat waktu ke  $t$ , dan dirumuskan sebagai

$$P_r(S_{t+1} = i | F_t) = p_{i1} P_r(S_t = 1 | F_t) + p_{i2} P_r(S_t = 2 | F_t) + p_{i3} P_r(S_t = 3 | F_t).$$

### 3. METODE PENELITIAN

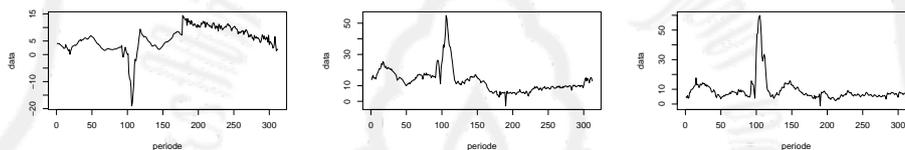
Penelitian ini menggunakan data selisih suku bunga pinjaman dengan simpanan, suku bunga simpanan riil, dan selisih BI *rate* riil dengan Fed *rate* riil mulai bulan Januari 1990 sampai bulan Desember 2015 yang diperoleh dari *International Financial Statistics (IFS)*. Data diolah dengan bantuan *software R*. Langkah-langkah yang dilakukan untuk mencapai tujuan penelitian sebagai berikut.

- (1) Membuat *plot* data kemudian melakukan uji kestasioneran data menggunakan uji *augmented Dickey Fuller (ADF)*. Jika data tidak stasioner, maka dilakukan transformasi log *return*.

- (2) Membuat *plot autocorrelation function (ACF)* dan *partial autocorrelation function (PACF)* dari data transformasi, kemudian membentuk model *AR-MA* terbaik dan dilanjutkan uji efek heteroskedastisitas pada residu model *ARMA* dengan menggunakan uji *Lagrange Multiplier (LM)*.
- (3) Membentuk model volatilitas terbaik.
- (4) Membentuk gabungan model volatilitas dan *Markov switching* dengan menggunakan asumsi tiga *state*.
- (5) Menghitung nilai *smoothed probability* dan nilai peramalan *smoothed probability* untuk mendeteksi krisis.

#### 4. HASIL DAN PEMBAHASAN

4.1. **Plot Data dan Transformasi Data.** *Plot* data ketiga indikator dapat dilihat pada Gambar 1. Data 1 merupakan data selisih suku bunga pinjaman dengan simpanan, data 2 merupakan data suku bunga simpanan riil, dan data 3 merupakan data selisih *BI rate* riil dengan *Fed rate* riil.



Gambar 1. (a) *Plot* Data 1, (b) *Plot* Data 2, dan (c) *Plot* Data 3

Gambar 1 (a), (b), dan (c) menunjukkan pola data yang tidak stasioner dimana data tidak berfluktuasi di sekitar rata-rata. Setelah dilakukan uji *ADF*, diperoleh probabilitas uji untuk data 1, 2 dan 3 berturut-turut sebesar 0,2228; 0,1028; dan 0,1467 yang lebih besar dari tingkat signifikansi  $\alpha = 0,05$ . Hal ini menyebabkan  $H_0$  uji *ADF* tidak ditolak yang artinya terdapat akar unit atau ketiga data tidak stasioner. Oleh karena itu, dilakukan transformasi *log return* untuk menstasionerkan ketiga data tersebut. Setelah dilakukan uji *ADF* terhadap ketiga data *log return*, diperoleh probabilitas uji ketiga data *log return* sebesar 0,01 yang lebih kecil dari tingkat signifikansi  $\alpha = 0,05$ . Hal ini menyebabkan  $H_0$  uji *ADF* ditolak yang artinya tidak terdapat akar unit atau ketiga data *log return* sudah stasioner.

4.2. **Pembentukan Model Rata-Rata Terbaik.** Ketiga data *log return* yang sudah stasioner selanjutnya dimodelkan menggunakan model *ARMA*. Orde tertinggi *AR* dan *MA* ditentukan dari plot *ACF* dan *PACF* dari data *log return*. *Plot ACF* dan *PACF* untuk ketiga data *log return* terputus setelah lag pertama yang berarti model *ARMA* yang sesuai untuk ketiganya yaitu *ARMA*(1,1), *ARMA*(1,0), dan *ARMA*(0,1). Model *ARMA* terbaik diperoleh berdasarkan nilai *AIC* terkecil untuk ketiga data adalah model *ARMA*(1,0). Model *ARMA*(1,0) untuk data 1 adalah  $r_t = 0,1576r_{t-1} + a_t$ , model *ARMA*(1,0) untuk data 2 adalah  $r_t = 0,13237r_{t-1} + a_t$ , dan model *ARMA*(1,0) untuk data 3 adalah  $r_t = 0,34296r_{t-1} + a_t$ .

Selanjutnya, dilakukan uji Lagrange *Multiplier* (*LM*) pada residu model ( $a_t$ ) untuk mengetahui ada tidaknya efek heterokedastisitas pada ketiga model *AR-MA*(1,0). Diperoleh probabilitas uji berturut-turut sebesar  $2,2 \times 10^{-12}$ ,  $8,616 \times 10^{-10}$ , dan  $1,021 \times 10^{-14}$  yang lebih kecil dari tingkat signifikansi  $\alpha = 0,05$ . Hal ini menyebabkan  $H_0$  uji *LM* ditolak yang artinya terdapat efek heteroskedastisitas pada ketiga model.

**4.3. Pembentukan Model Volatilitas Terbaik.** Untuk mengatasi efek heterokedastisitas, dibentuk model volatilitas. Orde dari model *ARCH* yang sesuai dapat diketahui melalui plot *PACF* residu kuadrat dari model *ARMA*. Nilai *PACF* residu kuadrat data 1 pada lag pertama, keempat dan kelima yang keluar dari pita konfidensi sedangkan pada lag lainnya sudah masuk dalam pita konfidensi. Diperoleh model *ARCH* yang sesuai yaitu *ARCH*(1). Model *ARCH* dengan orde yang lebih tinggi memiliki parameter yang tidak signifikan. Dibentuk model *GARCH*(1,1) untuk memperbaiki model *ARCH*(1) yang tidak bisa memuat lag keempat dan kelima. Semua parameter pada model *GARCH*(1,1) signifikan dan tidak menunjukkan adanya unsur asimetris melalui uji *Leverage effect*. Nilai *AIC* model *GARCH*(1,1) lebih kecil dibandingkan model *ARCH*(1). Berdasarkan hal tersebut, model volatilitas terbaik yaitu model *GARCH*(1,1) yang dapat dituliskan sebagai  $\sigma_t^2 = 0,00001522 + 0,1113a_{t-1}^2 + 0,7399\sigma_{t-1}^2$ .

Menggunakan cara yang sama pada data 1, diperoleh model volatilitas terbaik untuk data 2 yaitu model *GARCH*(1,1) yang dapat dituliskan sebagai  $\sigma_t^2 = 0,00001084 + 0,1762a_{t-1}^2 + 0,7833\sigma_{t-1}^2$  dan untuk data 3 yaitu model *GARCH*(1,1) yang dapat dituliskan sebagai  $\sigma_t^2 = 0,00004120 + 0,8552a_{t-1}^2 + 0,2523\sigma_{t-1}^2$ .

**4.4. Gabungan Model Volatilitas dengan Markov *Switching*.** Untuk dapat mendeteksi pengaruh perbedaan antara kondisi krisis, rawan dan stabil terhadap volatilitas dari ketiga data, digunakan gabungan model *GARCH*(1,1) dengan model Markov *switching* yaitu model *MS-GARCH*(1,1) dengan asumsi tiga *state*. Tiga *state* terdiri dari *state* dengan volatilitas rendah, sedang, dan tinggi. Diperoleh matriks transisi untuk data 1, 2, dan 3 berturut-turut sebagai  $P_1$ ,  $P_2$ , dan  $P_3$ .

$$P_1 = \begin{pmatrix} 0,99103 & 0,13188 & 0,9997610 \\ 0,00467 & 0,86810 & 5,7 \times 10^{-11} \\ 0,00430 & 0,00002 & 0,0002390 \end{pmatrix} \quad P_2 = \begin{pmatrix} 0,99066 & 0,97811 & 0,0000065 \\ 0,00011 & 0,00751 & 0,0849647 \\ 0,00923 & 0,01438 & 0,9150288 \end{pmatrix}$$

$$P_3 = \begin{pmatrix} 0,9901186 & 3,773934 \times 10^{-9} & 0,1082416 \\ 0,0000463 & 0,9098379 & 0,0073395 \\ 0,0098351 & 0,0901621 & 0,8844189 \end{pmatrix}.$$

Berdasarkan  $P_1$  dapat diketahui bahwa probabilitas *state* dari volatilitas rendah akan tetap di volatilitas rendah pada periode selanjutnya sebesar 0,99103, akan pindah ke volatilitas sedang sebesar 0,00467; dan akan pindah ke volatilitas

tinggi sebesar 0,00430. Probabilitas *state* dari volatilitas sedang akan pindah ke volatilitas rendah pada periode selanjutnya sebesar 0,13188, akan tetap di volatilitas sedang sebesar 0,86810, dan akan pindah ke volatilitas tinggi sebesar 0,00002. Probabilitas *state* dari volatilitas tinggi akan pindah ke volatilitas rendah pada periode selanjutnya sebesar 0,0999761, akan pindah ke volatilitas sedang sebesar  $5,7 \times 10^{-11}$ , dan akan tetap di volatilitas tinggi sebesar 0,000239. Hal ini menunjukkan bahwa perpindahan *state* yang mudah terjadi yaitu dari volatilitas rendah tetap di volatilitas rendah, dari volatilitas sedang tetap di volatilitas sedang, dan dari volatilitas tinggi menuju ke volatilitas rendah.

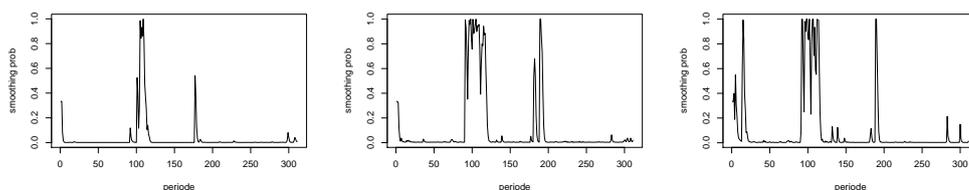
Diperoleh hasil estimasi parameter model *MS-GARCH*(1,1) untuk data 1, 2, dan 3 berturut-turut sebagai  $\sigma_{t1}^2$  dan  $\mu_{t1}$ ,  $\sigma_{t2}^2$  dan  $\mu_{t2}$ , serta  $\sigma_{t3}^2$  dan  $\mu_{t3}$ .  $\mu_t$  menggambarkan rata-rata data dan  $\sigma_t^2$  menggambarkan fluktuasi data pada masing-masing *state*.

$$\mu_{t1} = \begin{cases} -0,0003, & \text{state 1,} \\ 0,0071, & \text{state 2,} \\ -0,0045, & \text{state 3.} \end{cases} \quad \sigma_{t1}^2 = \begin{cases} 0,00010 + 0,2021 a_{t-1}^2 + 0,00010 \sigma_{t-1}^2, & \text{state 1,} \\ 0,00010 + 0,0001 a_{t-1}^2 + 0,95097 \sigma_{t-1}^2, & \text{state 2,} \\ 0,00057 + 0,00397 a_{t-1}^2 + 0,80944 \sigma_{t-1}^2, & \text{state 3.} \end{cases}$$

$$\mu_{t2} = \begin{cases} -0,0001, & \text{state 1,} \\ -0,0013, & \text{state 2,} \\ 0,0008, & \text{state 3.} \end{cases} \quad \sigma_{t2}^2 = \begin{cases} 0,000100 + 0,0324 a_{t-1}^2 + 0,0001 \sigma_{t-1}^2, & \text{state 1,} \\ 0,000296 + 0,0002 a_{t-1}^2 + 0,0356 \sigma_{t-1}^2, & \text{state 2,} \\ 0,001312 + 0,0553 a_{t-1}^2 + 0,1415 \sigma_{t-1}^2, & \text{state 3.} \end{cases}$$

$$\mu_{t3} = \begin{cases} -0,00014, & \text{state 1,} \\ 0,00252, & \text{state 2,} \\ 0,00075, & \text{state 3.} \end{cases} \quad \sigma_{t3}^2 = \begin{cases} 0,00010 + 0,00599 a_{t-1}^2 + 0,00010 \sigma_{t-1}^2, & \text{state 1,} \\ 0,00021 + 0,01113 a_{t-1}^2 + 0,05693 \sigma_{t-1}^2, & \text{state 2,} \\ 0,00217 + 0,10824 a_{t-1}^2 + 0,00703 \sigma_{t-1}^2, & \text{state 3.} \end{cases}$$

**4.5. Pendeteksian Dini Krisis Keuangan di Indonesia.** Berdasarkan model *MS-GARCH*(1,1) untuk data 1, 2, dan 3, diperoleh nilai *smoothed probability* untuk setiap *state*-nya. Pemilihan kriteria *state* beserta batasnya untuk mendeteksi krisis dilakukan dengan mempertimbangkan periode asli terjadinya krisis yaitu pada pertengahan tahun 1997 hingga tahun 1998.



Gambar 2. *Plot Smoothed Probability* untuk (a) Data 1, (b) Data 2, dan (c) Data 3

Gambar 2 merupakan *plot smoothed probability* data 1, 2, dan 3. Kondisi krisis pada data 1 dapat dilihat dari nilai *smoothed probability* lebih dari 0,1 di *state* 2,

pada data 2 lebih dari 0,6 di *state* 3, sedangkan pada data 3 lebih dari 0,6 di *state* 3. Tabel 1 menunjukkan periode krisis berdasarkan data 1, 2, dan 3 pada tahun 1997 dan 1998.

Tabel 1. Periode Krisis yang Terdeteksi pada Tahun 1997 dan 1998 beserta nilai *Smoothed Probability*-nya

Data	Periode	<i>Smoothed Probability</i>
Data 1	September 1997, Juni 1998, Juli - Desember 1998	0,1180; 0,5241 0,3939; 0,1160; 0,2971; 0,9843; 0,8421; 0,9306
Data 2	Agustus - Oktober 1997, Desember 1997, Januari - Juni 1998 Juli - Desember 1998	0,9937; 0,9296; 0,6811 0,7729; 0,9901; 0,9571; 0,9999; 0,8407; 0,7564; 0,9983; 0,8831; 0,9109; 0,9601; 0,9996; 0,8989; 0,9443
Data 3	September - November 1997, Januari - Juni 1998, Juli - Agustus 1998, Oktober - Desember 1998,	0,9999; 0,9963; 0,6167; 0,9809; 0,9002; 0,9999; 0,9999; 0,8641; 0,8341; 0,9997; 0,6596 0,8227; 0,9977; 0,9999

Tabel 2 merupakan nilai peramalan dan nilai aktual *smoothed probability* untuk data 1, 2, dan 3 pada bulan Januari hingga Desember 2016.

Tabel 2. Nilai Peramalan dan Aktual *Smoothed Probability*

Data 1		Data 2		Data 3	
Peramalan	Aktual	Peramalan	Aktual	Peramalan	Aktual
0,011343	0,00863	0,02646	0,00604	0,02142	0,00339
0,014445	0,00957	0,03320	0,00471	0,02859	0,00431
0,017123	0,00957	0,03931	0,00371	0,03489	0,00431
0,019435	0,00957	0,04485	0,00365	0,04041	0,00413
0,021431	0,00702	0,04987	0,00324	0,04525	0,00413
0,023155	0,00551	0,05441	0,00324	0,04951	0,00362
0,024644	0,00551	0,05854	0,00324	0,05326	0,00346
0,025929	0,00551	0,06227	0,00324	0,05656	0,00346
0,027039	0,00283	0,06566	0,00337	0,05946	0,00346
0,027998	0,00283	0,06873	0,00337	0,06203	0,00346
0,028825	0,01147	0,07151	0,00416	0,06429	0,00378
0,029539	0,01147	0,07403	0,00574	0,06629	0,00441

Tabel 2 menunjukkan nilai peramalan tidak berbeda jauh dengan nilai aktual sehingga model *MS-GARCH(1,1)* pada data 1, 2, dan 3 dapat digunakan untuk mendeteksi krisis. Tabel 3 merupakan nilai peramalan *smoothed probability* untuk data 1, 2, dan 3 di tahun 2017.

Tabel 3 menunjukkan bahwa nilai peramalan *smoothed probability* untuk data 1 kurang dari 0,04 di *state* 2, untuk data 2 kurang dari 0,3 di *state* 3, dan untuk data 3 kurang dari 0,22 sehingga semua nilai peramalan berada di kondisi stabil.

Tabel 3. Nilai Peramalan *Smoothed Probability* Data 1, 2, dan 3

Periode	Peramalan <i>Smoothed Probability</i>		
	Data 1	Data 2	Data 3
Januari 2017	0,01455	0,01442	0,01369
Februari 2017	0,01721	0,02229	0,02182
Maret 2017	0,01951	0,02942	0,02893
April 2017	0,02150	0,03589	0,03517
Mei 2017	0,02321	0,04174	0,04065
Juni 2017	0,02469	0,04705	0,04545
Juli 2017	0,02597	0,05187	0,04968
Agustus 2017	0,02707	0,05622	0,05339
September 2017	0,02803	0,06017	0,05667
Oktober 2017	0,02885	0,06376	0,05956
November 2017	0,02956	0,06701	0,06210
Desember 2017	0,03017	0,06995	0,06435

Indonesia diramalkan tidak mengalami krisis keuangan di tahun 2017 berdasarkan data 1, 2, dan 3.

## 5. SIMPULAN

Berdasarkan hasil dan pembahasan diperoleh kesimpulan sebagai berikut.

- (1) Gabungan model volatilitas dan Markov *switching* yang sesuai untuk mendeteksi krisis keuangan di Indonesia berdasarkan indikator selisih suku bunga pinjaman dengan simpanan, suku bunga simpanan riil, dan selisih BI *rate* riil dengan Fed *rate* riil adalah *MS-GARCH*(1,1),
- (2) Berdasarkan indikator selisih suku bunga pinjaman dengan simpanan, suku bunga simpanan riil, dan selisih BI *rate* riil dengan Fed *rate* riil, Indonesia diperkirakan tidak mengalami krisis keuangan di tahun 2017.

## DAFTAR PUSTAKA

- [1] Gray, S.F., *Modeling the Conditional Distribution of Interest Rates as A Regime-Switching Process*, Journal of Finance Economics 42(1996), 27-62.
- [2] Hamilton, J.D. and Susmel, R., *Autoregressive Conditional Heteroscedasticity and Changes in Regime*, Journal of Econometrics 64 (1994), 307-333.
- [3] Henry, T.O., *Between The Rock and a Hard Place: Regime Switching in the Relationship Between Short-Term Interest Rates and Equity Returns in the UK*, Department of Economics, The University of Melbourne, Victoria, Australia, 2007.
- [4] Kaminsky, G., Lizondo S., Reinhart C. M., *Leading Indicators of Currency Crises*, IMF Staff Papers, 1998.
- [5] Kuan, C. M., *lecture on Markov Switching Model*, Institute of Economics Academy Sinica, Taipei, Taiwan, 2002.
- [6] Mwamba, J.M. and Majadibodu, T., *Implied Volatility of Foreign Exchange Option: A Leading Indicator for Currency Crisis Identification*, African Journal of Business Management 6(2012), 10766-10774.
- [7] Sopipan, N., P. Sattayaham, B. Premanode, *Forecasting Volatility of Gold Using Markov Regime Switching and Trading Strategy*, Journal of Mathematical Finance 2 (2012), 121-131.
- [8] Tsay, R.S., *Analysis of Financial Time Series*, John Wiley and Sons, 2005.